



HAL
open science

Classification des perturbations présentes dans les réseaux électriques avec des descripteurs temps-fréquence et des approches d'apprentissage machine

Gandorj Darambazar, Ali Moukadem, Bruno Colicchio, Patrice Wira

► To cite this version:

Gandorj Darambazar, Ali Moukadem, Bruno Colicchio, Patrice Wira. Classification des perturbations présentes dans les réseaux électriques avec des descripteurs temps-fréquence et des approches d'apprentissage machine. Congrès National de la Recherche des IUT, Université de Haute-Alsace (UHA) Mulhouse - Colmar [Université de Haute-Alsace (UHA)], Mar 2024, Mulhouse, France. hal-04619719

HAL Id: hal-04619719

<https://hal.science/hal-04619719v1>

Submitted on 21 Jun 2024

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Classification des perturbations présentes dans les réseaux électriques avec des descripteurs temps-fréquence et des approches d'apprentissage machine

Gandorj Darambazar¹ Ali Moukadem¹ Bruno Colicchio¹ Patrice Wira¹
gandorj.darambazar@uha.fr ali.moukadem@uha.fr bruno.colicchio@uha.fr patrice.wira@uha.fr

¹ IUT de Mulhouse, Université de Haute Alsace
IRIMAS - Institut de Recherche en Informatique, Mathématiques, Automatique et Signal, UR 7499

THÈMES – *Traitement du Signal - Énergie - Informatique*

RÉSUMÉ – *De par leur nature, les réseaux électriques sont des systèmes distribués et complexes. Chaque appareil connecté au réseau peut modifier ses caractéristiques. Certains appareils peuvent consommer de l'énergie, on parle de charges, d'autres peuvent en injecter et ils sont alors considérés comme des sources. Avec tous les appareils connectés, il faut maintenir au sein du réseau un signal parfaitement sinusoïdal qui est défini par une amplitude, une fréquence fondamentale et une phase. Ceci est d'autant plus difficile que le nombre de charges et de sources ne cessent d'augmenter. En consommant l'énergie de manière discontinue, les sources détériorent le signal électrique ou le pollue. En injectant dans le réseau de l'énergie – issue par exemple de sources renouvelables – à travers de signaux non sinusoïdaux, qui n'ont pas la même fréquence fondamentale ou qui ne sont pas en phase avec le signal du réseau, celui-ci est détérioré. Maintenir le signal du réseau parfaitement sinusoïdal est un enjeu majeur pour garantir non seulement son bon fonctionnement mais également pour réduire les pertes. Cette étude explore l'utilisation d'algorithmes d'apprentissage machine (Machine Learning - ML) pour la classification et l'identification des perturbations impactant la qualité de l'énergie (Power Quality - PQ) dans les réseaux électriques. La première étape est la création d'une base de données labellisée qui est essentielle pour la validité de l'étude. La deuxième étape propose dix descripteurs discriminants et basés sur des méthodes temps-fréquence optimisées, assurant ainsi précision et robustesse, même dans diverses conditions de bruit. Dans la troisième étape, trois algorithmes de ML ont été sélectionnés pour classifier les perturbations générées par les appareils, il s'agit de l'approche K-NN (K-Nearest Neighbours), de l'approche SVM (Support Vector Machine), et du RF (Random Forest). Leurs performances sont testées et évaluées avec une analyse comparative de leurs résultats pour mettre en évidence leurs forces et leurs limites dans la tâche spécifique de classification des perturbations affectant la qualité de l'énergie électrique.*

MOTS-CLÉS – *Qualité de l'énergie électrique, réseau électrique, perturbation, classification, machine learning.*

1 Introduction

Dans les réseaux électriques, les perturbations de la qualité de l'énergie (Power Quality - PQ) représentent un enjeu majeur. Elles affectent non seulement le transport de l'énergie, mais provoquent également des dysfonctionnements de certains équipements. Ces perturbations sont générées par les appareils qui consomment de l'énergie, mais également par des sources qui injectent de l'énergie dans le réseau et qui sont de plus en plus nombreuses. Elles entraînent généralement des pertes économiques significatives. La Figure 1 montre le schéma d'un réseau de distribution triphasé qui intègre de multiples sources d'énergie. Une des grandeurs physiques particulièrement suivies est la fréquence fondamentale du signal sinusoïdal [1] mais elle ne suffit pas à elle seule à refléter la qualité du signal qui peut être perturbé par des chutes de tension, des surtensions, des interruptions, des composantes harmoniques, et des défauts combinés [2].

Cet article introduit dix descripteurs innovants destinés à classifier et identifier les défauts d'un signal électrique. Ces dix descripteurs sont calculés par des méthodes temps-fréquence à partir de signaux mesurés avec différents niveaux de bruit. En conséquence, nous avons constitué une base de données labellisée contenant des descripteurs temps-fréquence innovants. Puis, nous avons sélectionné trois algorithmes d'apprentissage machine (Machine Learning - ML) pour classifier les perturbations PQ. Les approches ML sont évaluées et les résultats sont détaillés et comparés.

L'objectif est de montrer l'efficacité des descripteurs et des algorithmes de ML dans la classification des perturbations électriques pour contribuer à une meilleure gestion et stabilité des réseaux électriques en temps-réel. Un schéma de détection et de classification des perturbations PQ est proposé par la Figure 2.

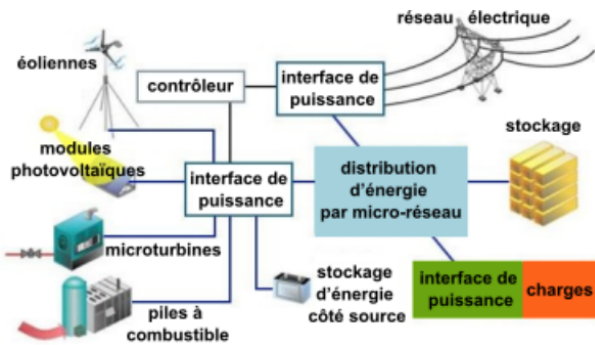


FIGURE 1 – Schéma d'un système complexe de distribution de l'énergie électrique

2 Extraction des descripteurs

Le processus d'extraction des descripteurs s'effectue à partir d'un signal mesuré sur le réseau électrique et à l'aide de méthodes de traitement du signal [3]. Les méthodes choisies sont basées à la fois sur des informations calculées dans l'espace du temps et dans l'espace des fréquences et sont dites « temps-fréquences ». Nous pouvons citer la transformée de Fourier à court terme (Short Term Fourier Transform - STFT), la Transformée de Stockwell (TS) et une Transformée de Stockwell Optimisée (TSO) [4]. Les dix descripteurs temps-fréquence, désignés par F_i où i varie de 1 à 10, sont extraits pour saisir les aspects fondamentaux du signal tant en termes de variations temporelles que fréquentielles. Les dix descripteurs temps-fréquence proposés sont [5] :

- F_1 : le nombre de composants en fonction du temps qui est différent de la distorsion harmonique totale (Total Harmonic Distortion - THD) ;
- F_2 : le rapport d'entropie de Shannon obtenu par des méthodes temps-fréquence ;
- F_3 : la concentration d'énergie issue des méthodes temps-fréquence qui est une mesure statistique évaluant la qualité de la représentation temps-fréquence ;
- $F_4, F_5,$ et F_6 : des caractéristiques transitoires basées sur l'énergie de Shannon et qui décrivent la forme des signaux transitoires à des fréquences spécifiques (60, 180 et 300 Hz) ;
- $F_7, F_8, F_9,$ et F_{10} : des paramètres contrôlant la fenêtre glissante de la méthode OST et qui sont obtenus en maximisant la concentration énergétique F_3 .

3 Classification par des algorithmes d'apprentissage machine

Des signaux avec différentes perturbations PQ ont été générés avec différents niveaux de bruits. Des signaux sans perturbations ont également été pris en compte. A partir de tous ces signaux, les descripteurs sont calculés et l'ensemble constitue la base d'apprentissage labellisée pour les algorithmes ML de classification. A cause de la quantité




FIGURE 2 – Stratégie de classification des perturbations PQ dans les réseaux électriques

de données et de leur diversité, la tâche de classification des perturbations PQ nécessite des algorithmes avancés tels que les techniques ML. Cette étude évalue des algorithmes ML tels que les K-Nearest Neighbors (K-NN) [6], le Random Forest (RF) [7] et le Support Vector Machine (SVM) [8]. Ces algorithmes sont entraînés avec les dix descripteurs temps-fréquence F_i précédemment définis. La classification consiste à reconnaître la classe \hat{C}_i caractérisant les distorsions de la forme d'onde et les écarts par rapport à la forme d'onde sinusoidale idéale sans connaissances a priori autre que les valeurs calculées des descripteurs.

La base de données utilisées par les techniques ML pour la classification est constituée de la manière suivante. Des signaux sinusoidaux avec une période d'échantillonnage $T_s = 1$ ms et, sans perte de généralité, avec une fréquence fondamentale de $f = \frac{1}{T} = 60$ Hz ont été générés. A ceux sans perturbations sont ajoutés des perturbations de 10 différents types [5]. Nous avons généré un total de 1 000 événements PQ avec 100 réalisations pour chacune des 10 classes C_i et ceci sans bruit et avec du bruit gaussien de 20 dB et de 5 dB. La durée de chaque signal est de 1 seconde et chaque événement PQ au sein d'un signal a une durée de 80 ms. Les descripteurs ont été calculés pour tous les signaux en utilisant des méthodes temps-fréquence STFT, ST et OST [3]. Ces données constituent une base de données composée de 108 000 enregistrements, 75 % ont été sélectionnées aléatoirement pour l'apprentissage et les 25 % restants ont été utilisés pour les tests de classification.

4 Résultats et analyse

Une analyse détaillée des performances de classification des événements PQ a été réalisée et les résultats sont synthétisés par la Figure 3. Cette figure montre les taux de classification en considérant uniquement les 3, 4 ou 6 premiers descripteurs ainsi qu'avec les 10 descripteurs \hat{F}_i . Ces résultats

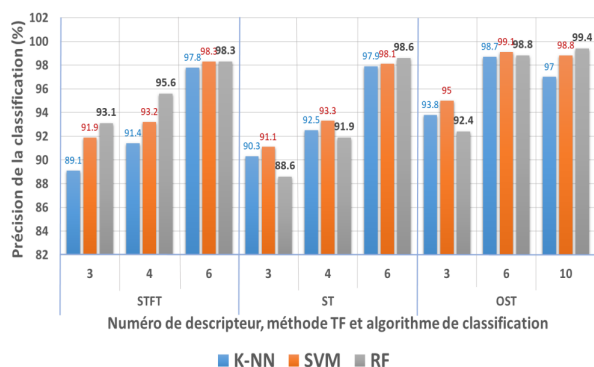


FIGURE 3 – Taux de classification (%) des perturbations PQ en fonction de la méthode temps-fréquence et du nombre de descripteurs avec un niveau de bruit maximum de 5 dB et en fonction des trois approches ML

sont affichés pour les 3 méthodes TF. L'approche RF présente un taux de classification de 99,4% dans chaque scénario de perturbations PQ et de bruit. Les algorithmes K-NN et SVM ont, quant à eux, atteint un taux de classification supérieur à 97% dans les mêmes conditions de test avec les 10 descripteurs. Dans certains cas, la précision de la classification a atteint 100%, notamment lorsque le rapport signal sur bruit (SNR) est élevé. Même en utilisant que les 6 premiers descripteurs, toutes les approches classifient les événements PQ avec un taux supérieur à 97%. Il en ressort que les descripteurs proposés sont capables de discriminer efficacement les différents types de perturbation PQ, même en présence de bruit.

5 Conclusions

Cette étude propose dix nouveaux descripteurs temps-fréquence pour représenter et discriminer les perturbations PQ présentes dans les réseaux électriques. Utilisés par des approches d'apprentissage machine, ils permettent d'identifier le type de perturbation PQ en atteignant un taux de classification de 99,4 % ce qui surpasse les études similaires, surtout dans des conditions de bruit sévères.

Références

- [1] G. Darambazar, B. Colicchio, A. Moukadem, P. Wira, *Boucles à verrouillage de phase pour l'estimation de la fréquence instantanée dans les réseaux électriques de distribution*. Congrès National de la Recherche des IUT 2021 (CNRIUT 2021), Lyon, France, 3-4 Juin, 2021
- [2] A. Baggini (Eds.), *Handbook of Power Quality*. Edition Wiley, 2008.
- [3] F. de Coulon, *Théorie et traitement des signaux*, EPFL Press, 1996
- [4] F. Hlawatsch, F. Auger (Eds.), *Time-Frequency Analysis, Concepts and Methods*. Ouvrage collectif, Editions ISTE and Wiley, 2018
- [5] G. Darambazar, B. Colicchio, A. Moukadem, P. Wira, *Applying Machine Learning Algorithms for Classifying Time-Frequency Failures in Power Grid Systems*. Upper Rhine Artificial Intelligence symposium (URAI 2023), Mulhouse, France, 16-17 Nov., 2023
- [6] U. Shahadat, H. Ibtisham, L. Mohammad Ali, G. Ergun, *Comparative performance analysis of K-NN algorithm and its different variants for disease prediction*, Scientific Reports, vol. 12, no. 1, April 2002
- [7] L. Breiman, *Random Forests*, Machine Learning, vol. 45, no. 1, Oct 2001, p. 5-32
- [8] R. Latha, Ch. Sai Babu, K. Prasad *Detection & Analysis of Power Quality Disturbances using Wavelet Transforms and SVM*, IRJ of Signal Processing, vol. 2, no. 2, Dec 2011, p. 58-69